

<https://doi.org/10.21122/2227-1031-2021-20-4-345-351>

УДК 629.3; 004.42

## Использование искусственных нейронных сетей для определения износа композиционного фрикционного материала

Кандидаты техн. наук, доценты А. В. Лешок<sup>1)</sup>, Ю. Б. Попова<sup>2)</sup>

<sup>1)</sup>Государственное научное учреждение «Институт порошковой металлургии имени академика О. В. Романа» (Минск, Республика Беларусь),

<sup>2)</sup>Белорусский национальный технический университет (Минск, Республика Беларусь)

© Белорусский национальный технический университет, 2021  
Belarusian National Technical University, 2021

**Реферат.** Спеченные фрикционные материалы широко используются в узлах трения автотракторной техники, техники специального назначения. Основная цель – передача крутящего момента на исполнительный механизм. Развитие рынка техники требует разработки и применения новых узлов. Одновременно с этим необходимо создание новых материалов, это относится и к спеченным фрикционным. Данная группа материалов характеризуется высоким ресурсом работы, эффективностью передачи крутящего момента, а также способностью восстановления работоспособности в случае нарушения режимов эксплуатации. Одним из наиболее существенных параметров, характеризующих спеченный фрикционный материал, является износостойкость. В большинстве случаев она определяет не только ресурс работы самого узла, но и всей машины в целом. Особое место занимают тормозные узлы, в которых также используются фрикционные материалы. Повышенная износостойкость фрикционного материала способствует снижению эффективности и ресурса работы тормозной системы. Оценка износостойкости фрикционного материала под заданные эксплуатационные параметры – весьма длительный и материально затратный процесс. Разработка методов и способов ускорения оценки износостойкости – важная научная и практическая задача. В статье представлены результаты использования искусственных нейронных сетей для прогнозирования ресурса работы композиционного фрикционного материала на основе меди в зависимости от скорости скольжения, давления на материал и количества подаваемой смазки в зону трения. С использованием массива экспериментальных данных для фрикционного материала ФМ-15 была обучена искусственная нейронная сеть. Результаты обучения показали высокую точность, правильность предложенной и реализованной архитектуры сети. Разработанное программное обеспечение продемонстрировало свою работоспособность и возможность применения в расчетах для определения износа композиционного фрикционного материала.

**Ключевые слова:** фрикционный материал, коэффициент трения, износ, ресурс работы, искусственные нейронные сети

**Для цитирования:** Лешок, А. В. Использование искусственных нейронных сетей для определения износа композиционного фрикционного материала / А. В. Лешок, Ю. Б. Попова // *Наука и техника*. 2021. Т. 20, № 4. С. 345–351. <https://doi.org/10.21122/2227-1031-2021-20-4-345-351>

## Using Artificial Neural Networks to Determine Wear of Composite Friction Material

A. V. Liashok<sup>1)</sup>, Yu. B. Popova<sup>2)</sup>

<sup>1)</sup>The State Scientific Institution “Powder Metallurgy Institute” (Minsk, Republic of Belarus),

<sup>2)</sup>Belarusian National Technical University (Minsk, Republic of Belarus)

**Abstract.** Sintered friction materials are widely used in friction units of automotive vehicles and special purpose vehicles. The main purpose is to transmit torque to the actuator. The development of the technology market requires the development and use of new units. At the same time, the creation of new materials is required, which also applies to sintered friction

### Адрес для переписки

Попова Юлия Борисовна  
Белорусский национальный технический университет  
ул. Б. Хмельницкого, 9,  
220013, г. Минск, Республика Беларусь  
Тел.: +375 17 292-71-53  
[jpopova@bntu.by](mailto:jpopova@bntu.by)

### Address for correspondence

Popova Yuliya B.  
Belarusian National Technical University  
9, B. Khmel'nitsky str.,  
220013, Minsk, Republic of Belarus  
Tel.: +375 17 292-71-53  
[jpopova@bntu.by](mailto:jpopova@bntu.by)

materials. This group of materials is characterized by a high service life, efficiency of torque transmission, as well as the ability to restore performance in case of violation of operating modes. One of the most significant parameters characterizing a sintered friction material is wear resistance. In most cases, it determines not only the resource of the unit itself, but the entire machine as a whole. A special place is occupied by brake units, which also use friction materials. The increased wear resistance of the friction material contributes to a decrease in the efficiency and service life of the brake system. Evaluation of the wear resistance of a friction material for the given operational parameters is a very long and costly process. The development of methodology and methods for accelerating the assessment of wear resistance is an important scientific and practical task. The paper presents the results of using artificial neural networks to predict the service life of a composite friction material based on copper on the sliding speed, pressure on the material and the amount of lubricant supplied to the friction zone. An artificial neural network has been trained using an array of experimental data for the FM-15 friction material. The training results have shown high accuracy, correctness of the proposed and implemented network architecture. The developed software has demonstrated its efficiency and the possibility of using it in calculations to determine the wear of a composite friction material.

**Keywords:** friction material, coefficient of friction, wear, service life, artificial neural networks

**For citation:** Liashok A. V., Popova Yu. B. (2021) Using Artificial Neural Networks to Determine Wear of Composite Friction Material. *Science and Technique*. 20 (4), 345–351. <https://doi.org/10.21122/2227-1031-2021-20-4-345-351> (in Russian)

Быстрое развитие современной техники вызвало необходимость применения форсированных режимов работы узлов трения машин. Одновременно ставится вопрос о переходе на серийное производство машин без длительных натурно-производственных испытаний. Все это повышает требования к промежуточным ресурсным испытаниям триботехнических материалов и узлов трения. В то же время традиционный «ручной» однофакторный анализ при оценке результатов эксперимента нередко приводит к тому, что характеристики, полученные в лабораторном эксперименте, не могут быть воспроизведены при натурно-производственных испытаниях.

Долговечность и работоспособность узлов и механизмов определяются совокупностью факторов, один из которых – их предельное состояние [1]. В [1] также отмечается, что характеристикой предельного состояния является наработка, представляющая собой календарную продолжительность эксплуатации изделия до момента возникновения предельного состояния.

При использовании инновационной системы определения ресурса и обеспечения конкурентоспособности триботехнических систем задача сводится к оценке результатов экспериментальных исследований или существующей математической модели объекта. Все триботехнические системы находятся в состояниях, далеких от равновесия [2]. Это условие касается и триботехнических систем, имеющих свои специфику, законы, особенности, предполагающих индивидуальный подход [3]. В пределах нелинейной неравновесной области необходимо специальное исследование. В ряде случаев состояние оказывается неустойчивым, качественно отличаясь от стационарного. Исследование

подобных систем с учетом их нелинейности позволяет обнаружить новые явления, которые не наблюдаются в линейных (равновесных и слабо неравновесных) системах.

Показатель надежности работы фрикционного материала – износ, определяемый совокупностью параметров трибосистемы и находящийся в областях возможных значений параметров. Допустимые значения износа фрикционного материала регламентируются в [4–6] и являются показателем ресурса его работы.

Износ фрикционного материала определяется совокупностью факторов, таких как: конструкция узла и механизма, а также самого фрикционного диска; нагрузочно-скоростные режимы; эффективность организации граничного трения; цикличность фрикционного взаимодействия. Учет всех факторов весьма сложен. Поэтому ограничиваются несколькими из них. В большинстве случаев – это нагрузочно-скоростные режимы и эффективность организации граничного трения, определяемая количеством подаваемой смазки в зону трения (рис. 1).



Рис. 1. Основные факторы, влияющие на износ фрикционного материала

Fig. 1. Main factors affecting wear of friction material

Многокритериальность, многопараметричность, стохастичность и нелинейность триботехнических систем создают значительные трудности при прогнозировании их поведения. В большинстве случаев оценка износа композиционного фрикционного материала осуществляется экспериментальным путем, который состоит из нескольких этапов: сравнительные стендовые; стендовые, приближенные к натурным. Такие испытания достаточно длительные и предполагают существенные материальные, трудовые и энергетические затраты. В случае изменения одного из факторов в работе фрикционного материала требуется проведение повторных испытаний.

Известны расчетные методы оценки ресурса работы фрикционного материала, например, как в [7]. Метод основан на теоретическом анализе гидродинамических процессов и экспериментальных исследований в многодисковых фрикционных узлах. Износ фрикционного материала оценивается энергетической интенсивностью изнашивания, совокупностью коэффициентов, характеризующих энергетическое состояние в месте контакта и микрогеометрии поверхностей трения. Зависимость не учитыва-

ет эксплуатационных параметров, таких как количество смазки в зоне трения, изменение давления и скорости скольжения.

В [8] приведена методика оценки ресурса работы муфт сцепления, основанная на анализе феноменологической стороны процесса трения и изнашивания с помощью построенной математической модели буксования. Недостаток модели – невозможность ее применения для процессов сухого трения.

Использование компьютерной техники и программного обеспечения для моделирования различного рода процессов позволяет активно применять вероятностный подход при прогнозировании ресурса работы. В наибольшей степени этому условию удовлетворяют искусственные нейронные сети (ИНС). Так, для определения износа фрикционного материала ИНС дают возможность в реальном времени при изменении факторов проводить прогнозирование, не прибегая к стендовым испытаниям (рис. 2), существенно сокращая время и материально-технические ресурсы, а также формировать решение его использования в технически оптимальных узлах трения.

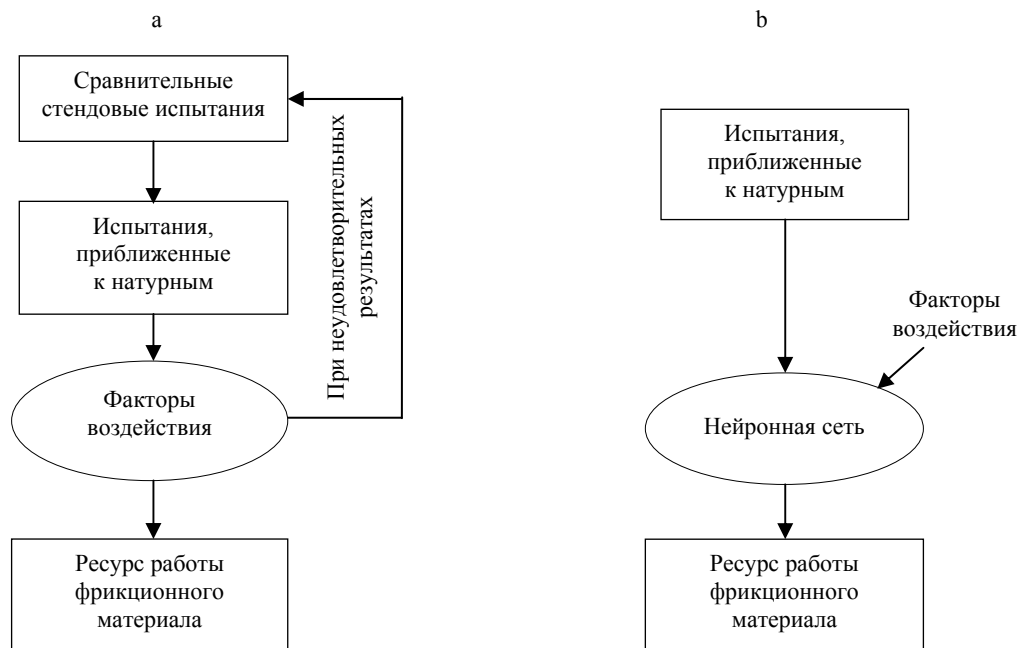


Рис. 2. Схема оценки износа композиционного фрикционного материала: а – традиционная; б – с использованием искусственных нейронных сетей

Fig. 2. Scheme for assessing wear of composite friction material: а – traditional; б – using artificial neural networks

Одним из основных преимуществ ИНС перед традиционными алгоритмами, как указано в [9], является возможность обучения сети на основании массива входных данных. Таким образом, чем больше количественный набор данных, тем качественно выше точность результата. При обучении ИНС входным данным (входам) ставится в соответствие определенный выход с одновременной подстройкой весов. Следует также отметить, что положительными моментами применения ИНС являются относительно простая аппаратная реализация, довольно высокое быстродействие и инвариантность к виду уравнений математической модели системы. То есть разработанные алгоритмы обучения, а также реализованное программное обеспечение могут быть применены для различных видов решаемых задач.

При разработке искусственной нейронной сети определяются с архитектурой ее построения на основании обучающей выборки с учетом двух условий [10]:

1) исходные данные должны быть непротиворечивы, т. е. одному набору входных данных не может соответствовать несколько выходных;

2) набор исходных данных должен быть полным, т. е. количество примеров, предоставляемых алгоритму обучения, должно быть достаточным, чтобы обеспечить его всей необходимой информацией для изучения зависимости.

На рис. 3 предложена архитектура сети для оценки износа композиционного фрикционного материала с тремя входами  $x_1$  (скорость вращения фрикционного диска),  $x_2$  (давление на материал),  $x_3$  (количество подаваемой смазки) и одним выходом  $y$  (износ материала).




Рис. 3. Графическое представление искусственной нейронной сети для прогнозирования износа фрикционного материала

Fig. 3. Graphical representation of artificial neural network for predicting wear of friction material

В настоящее время существует достаточно большое количество методов обучения ИНС, среди которых наиболее популярен метод обратного распространения ошибки. Он представляет собой итеративный градиентный алгоритм, который используется с целью минимизации ошибки работы многослойной ИНС, получения желаемого выхода и включает в себя три фазы: проведение через сеть обучающего примера (фаза прямого распространения); вычисление значения ошибки между полученным выходом сети и ожидаемым, на основе которого затем рассчитываются ошибки для каждого предыдущего слоя, вплоть до входного (фаза обратного распространения ошибки); единовременная корректировка всех весов, основанная на их текущем значении, величине ошибки, соответствующей рассматриваемому нейрону и активационному значению нейрона [11]. Функция ошибки для сети с  $J$  выходами задается следующим образом:

$$E(\bar{x}) = \sum_{j=J} (y_j - t_j)^2, \quad (1)$$

где  $\bar{x}$  – набор данных из обучающей выборки;  $y_j$  – реальный выход  $j$ -го нейрона сети;  $t_j$  – ожидаемый выход  $j$ -го нейрона.

Для того чтобы ИНС корректно работала, необходимо ее обучить, т. е. определить все веса. Перед началом обучения веса у сети представляются случайным способом. При вычислении выходов нейронов используется сигмоидальная функция активации. На вход функция обучения принимает уже определенные наборы данных (входы-выходы), которые заведомо верные.

На первоначальном этапе идет настройка системы, выставление количества итераций обучения и значения ошибки, которые являются важными показателями в обучении. Если превысить или уменьшить эти показатели, можно переобучить или недоучить систему. Поэтому обычно обучение проводится несколько раз с корректировкой этих параметров. На следующем этапе обучения реализуется проход по сети на основе входных данных для обучения. Результатом прохода являются выходные данные для корректировки весов. При вычислении выходов нейронов используется сигмоидальная функция активации. Затем происходит проход по ИНС в обратном направлении с вычислением значения ошибки, на основе которой в дальнейшем будет выполняться корректировка весов [12]. Значение веса  $w_{ij}$ , соответствующее синаптической связи, соединяющей  $i$ -й нейрон скрытого слоя с  $j$ -м нейроном следующего слоя, изменяется по формуле [13]

$$w_{ij}^{new} = w_{ij}^{old} + l e_j z_i, \quad (2)$$

где  $w_{ij}^{new}$ ,  $w_{ij}^{old}$  – новое и старое значения веса при связях, соединяющих  $i$ -й нейрон предыдущего слоя и  $j$ -й нейрон выходного слоя;  $l$  – количество итераций обучения;  $e_j$  – значение ошибки каждого нейрона выходного слоя;  $z_i$  – выходное значение  $i$ -го нейрона.

Для связей, соединяющих входной слой с первым скрытым слоем, (2) примет следующий вид:

$$w_{ij}^{new} = w_{ij}^{old} + l e_j x_i, \quad (3)$$

где  $x_i$  –  $i$ -й компонент входного вектора  $\bar{x}$ .

При обучении ИНС получает определенный набор весов, которые, если соответствуют ожиданиям, не изменяются, либо происходит корректировка значений допустимой ошибки или итераций обучения, и алгоритм запускается заново. Алгоритм работает до тех пор, пока не будет достигнут приемлемый уровень ошибки или не закончатся все итерации.

Для обучения сети использовались результаты стендовых испытаний влияния нагрузочно-скоростных режимов и количества подаваемой смазки на величину износа композиционного фрикционного материала ФМ-15. Данные были получены после 200 циклов испытаний при следующих режимах: скорость скольжения 1000–2500 м/с, давление на материал 10–25 атм, количество подаваемой смазки 0,5–1,0 л/мин.

Реализация модели прогнозирования износа фрикционного материала осуществлена на языке программирования JavaScript и библиотек Node.js и Underscore.js. В табл. 1 приведены фрагмент данных, используемых для обучения нейросети, результаты расчетов и величина среднеквадратичного отклонения.

Таблица 1

**Фрагмент результатов обучения нейросети оценке износа фрикционного материала ФМ-15 и величина среднеквадратичного отклонения**

**Fragment of results of training neural network for assessing wear of friction material FM-15 and value of mean-square deviation**

№	Скорость, м/с	Давление, атм	Количество масла, л/мин	Нормированная величина износа, (мкм/км)/100	Результат расчета, (мкм/км)/100	Среднеквадратичное отклонение
1	2250	15	0,5	0,0028	0,002833	0,000017
2	2250	15	0,6	0,0025	0,002568	0,000034
3	2250	15	0,7	0,0023	0,002333	0,000017
4	2250	15	0,8	0,0021	0,002126	0,000013
5	2250	15	0,9	0,0019	0,001944	0,000022
6	2250	15	1,0	0,0018	0,001783	0,000008
7	2250	16	0,5	0,0027	0,002718	0,000009
8	2250	16	0,6	0,0025	0,002466	0,000017
9	2250	16	0,7	0,0023	0,002244	0,000028
10	2250	16	0,8	0,0021	0,002048	0,000026
11	2250	16	0,9	0,0019	0,001874	0,000013
12	2250	16	1,0	0,0018	0,001721	0,000039
13	2250	17	0,5	0,0026	0,002609	0,000005
14	2250	17	0,6	0,0024	0,002370	0,000015
15	2250	17	0,7	0,0022	0,002159	0,000021
16	2250	17	0,8	0,0020	0,001973	0,000014
17	2250	17	0,9	0,0018	0,001809	0,000005
18	2250	17	1,0	0,0017	0,001663	0,000018

№	Скорость, м/с	Давление, атм	Количество масла, л/мин	Нормированная величина износа, (мкм/км)/100	Результат расчета, (мкм/км)/100	Среднеквадратичное отклонение
19	2250	18	0,5	0,0025	0,002506	0,000003
20	2250	18	0,6	0,0023	0,002279	0,000010
21	2250	18	0,7	0,0021	0,002079	0,000010
22	2250	18	0,8	0,0019	0,001902	0,000001
23	2250	18	0,9	0,0017	0,001746	0,000023
24	2250	18	1,0	0,0016	0,001608	0,000004
25	2250	19	0,5	0,0024	0,002408	0,000004
26	2250	19	0,6	0,0022	0,002193	0,000004
27	2250	19	0,7	0,0020	0,002003	0,000001
28	2250	19	0,8	0,0019	0,001835	0,000032
29	2250	19	0,9	0,0017	0,001687	0,000006
30	2250	19	1,0	0,0015	0,001556	0,000028
31	2250	20	0,5	0,0023	0,002316	0,000008
32	2250	20	0,6	0,0021	0,002112	0,000006
33	2250	20	0,7	0,0020	0,001931	0,000035
34	2250	20	0,8	0,0018	0,001772	0,000014
35	2250	20	0,9	0,0016	0,001631	0,000015
36	2250	20	1,0	0,0013	0,001507	0,000104

Копия экрана разработанного программного обеспечения представлена на рис. 4, где можно заметить, что существуют две возможности расчета износа материала: для определенного режима, задаваемого входными данными  $x_1$ ,  $x_2$ ,  $x_3$ , и для всей обучающей выборки. Результат расчета приведен для входных данных:  $x_1 = 2250$  м/с;  $x_2 = 15$  атм;  $x_3 = 1,0$  л/мин. При таких данных износ материала составил 0,18 мкм/км.

Расчет износа, мкм/км

Расчет всей обучающей выборки

Рассчитать

Скорость, м/с  
2250

Давление, атм  
15

Количество масла, л/м  
1

Износ = 0,18 мкм/км

Рис. 4. Результат расчета величины износа фрикционного материала ФМ-15 по заданным значениям скорости, давления и количества подаваемой смазки

Fig. 4. Result of calculating wear amount of friction material FM-15 according to specified values of speed, pressure and amount of supplied lubricant

Рис. 5 позволяет оценить точность полученных результатов расчета величины износа композиционного фрикционного материала ФМ-15, полученного экспериментальным и расчетным путем для фрагмента обучающей выборки, приведенной в табл. 1. По оси абсцисс отложены порядковые номера строчек табл. 1, а по оси ординат – износ фрикционного материала ФМ-15, (мкм/км)/100.




Рис. 5. Расчет износа фрикционного материала ФМ-15 для обучающей выборки по результатам:

— экспериментальным; — обучения нейросети

Fig. 5. Calculation on wear of friction material FM-15 for a training set according to results:

— experimental; — training of neural network

## ВЫВОДЫ

1. По полученным результатам можно сделать вывод, что использование искусственных нейронных сетей позволяет прогнозировать ресурс работы композиционного фрикционного материала в зависимости от скорости скольжения, давления на материал и количества подаваемой смазки в зону трения. Это – важный инструмент, снижающий материальные и трудовые ресурсы, исключая длительные стендовые и натурные испытания. Использование искусственных нейронных сетей может являться мощным инструментом в руках специалистов, проектирующих новую технику, позволяя определять габариты узлов и механизмов исходя из их целевого назначения.

2. Результаты расчета показали достаточную точность обучения искусственных нейрон-

ных сетей методом обратного распространения ошибки и доказали правильность предложенной и реализованной архитектуры сети.

3. Разработанное программное обеспечение продемонстрировало свою работоспособность и возможность применения в расчетах для определения износа композиционного фрикционного материала.

#### ЛИТЕРАТУРА

1. Надежность в технике. Термины и определения: ГОСТ 27.002–2015. Введ. 01.03.2017. М.: Стандартинформ, 2016. 24 с.
2. Сафонов, Б. П. Инженерная трибология: оценка износостойкости и ресурса трибосопрежений / Б. П. Сафонов, А. В. Бегова. Новомосковск: РХТУ имени Д. И. Менделеева, Новомосковский институт, 2004. 59 с.
3. Войтов, В. А. Моделирование процессов трения и изнашивания в трибосистемах в условиях граничной смазки. Часть 2. Результаты моделирования / В. А. Войтов, М. Б. Захарченко // Проблемы трибологии. 2015. № 2. С. 36–44.
4. Изделия фрикционные порошковые. Технические условия: ТУ БУ 100219793.431–2015. Введ. 24.09.2015. Минск: Гос. науч. учр. «Ин-т порошк. метал. имени акад. О. В. Романа», Госстандарт, 2015. 25 с.
5. Ильющенко, А. Ф. Спеченные металлокерамические фрикционные композиционные материалы и изделия / А. Ф. Ильющенко, А. А. Дмитриевич, А. В. Лешок // Весті Нацыянальнай акадэміі навук Беларусі. Серыя фізіка-тэхнічных навук. 2011. № 2. С. 10–17.
6. Влияние состава фрикционного материала на основе меди на его структуру и триботехнические свойства / А. В. Лешок [и др.] // Трение и износ. 2019. Т. 40, № 6. С. 654–660.
7. Юдин, Е. Г. Прогнозирование долговечности фрикционных узлов трансмиссий гусеничных машин / Е. Г. Юдин // Вестник МГТУ имени Н. Э. Баумана. Серия «Машиностроение». 2004. № 3. С. 3–14.
8. Сприжикский, И. А. Оптимизация конструкции и прогнозирование долговечности пар трения муфт сцепления / И. А. Сприжикский. Минск, 1984. 191 с.
9. Шилкин, Н. В. Нейросети: возможности использования алгоритмов самообучения в системах управления теплоэнергопотреблением зданий [Электронный ресурс] / Н. В. Шилкин, М. М. Бродач // АВОВ. 2019. № 4. Режим доступа: [https://www.abok.ru/for\\_spec/articles.php?nid=7229](https://www.abok.ru/for_spec/articles.php?nid=7229). Дата доступа: 10.12.2020.
10. Алтунин, К. А. Применение нейронных сетей для моделирования процесса токарной обработки / К. А. Алтунин, М. В. Соколов // Вестник ТГТУ. 2016. Т. 22, № 1. С. 122–133.
11. Попов, О. В. Определение предельного сопротивления дилатирующего грунта сдвигу при помощи искусственных нейронных сетей / О. В. Попов, Ю. Б. Попова, С. В. Яцынович // Наука и техника. 2018. Т. 17, № 6. С. 471–477. <https://doi.org/10.21122/2227-1031-2018-17-6-471-477>.
12. Попова, Ю. Б. Программная реализация искусственной нейронной сети для управления виртуальными объектами / Ю. Б. Попова, С. В. Яцынович // Системный анализ и прикладная информатика. 2017. № 4. С. 72–78. <https://doi.org/10.21122/2309-4923-2017-4-72-78>.
13. Тархов, Д. А. Нейронные сети. Модели и алгоритмы / Д. А. Тархов. М.: Радиотехника, 2005. 256 с.

#### REFERENCES

1. State Standard 27.002–2015. *Reliability in Technology. Terms and Definitions*. Moscow, Standartinform Publ., 2016. 24 (in Russian).
2. Safonov B. P., Begova A. V. (2004) *Engineering Tribology: Assessment of Wear Resistance and Resource of Tribocouplings*. Novomoskovsk, D. I. Mendelev University of Chemical Technology of Russia, Novomoskovsk Institute. 59 (in Russian).
3. Voytov V. A., Zakharchenko M. B. (2015) Modeling the Processes of Friction and Wear in Tribosystems under Boundary Lubrication Conditions. Part 2. Simulation Results. *Problemi Tribologii = Problems of Tribology*, (2), 36–44 (in Russian).
4. TU [Technical Specifications] BY 100219793.431–2015. *Powder Friction Products*. Minsk, The State Scientific Institution “Powder Metallurgy Institute Named after O. V. Roman”, Gosstandart Publ., 2015. 25 (in Russian).
5. Ilyushchenko A. Ph., Dmitrovich A. A., Leshok A. V. (2011) Sintered Metal-Ceramic Friction Composite Materials and Products. *Vesti Natsyanyal'noi Akademii Navuk Belarusi. Seriya Fizika-Tekhnichnykh Navuk = Proceedings of the National Academy of Sciences of Belarus. Physical-Technical Series*, (2), 10–17 (in Russian).
6. Leshok A. V., Dyachkova L. N., Ilyushchenko A. F., Rogovoy A. N., Alekseenko N. A. (2019) Influence of Copper Frictional Material Composition on Structure and Tribotechnical Properties. *Journal of Friction and Wear*, 40 (6), 495–500. <https://doi.org/10.3103/s1068366619060151>.
7. Yudin E. G. (2004) Prediction on Durability of Friction Units in Transmissions of Tracked Vehicles. *Vestnik MG TU imeni N. E. Bauman = Herald of the Bauman Moscow State Technical University. Series Mechanical Engineering*, (3), 3–14 (in Russian).
8. Sprizhetskii I. A. (1984) *Optimization of Design and Prediction of Durability of Friction Pairs of Clutch Couplings*. Minsk. 191 (in Russian).
9. Shilkin N. V., Brodach M. M. (2019) Neural Networks: Possibilities of Using Self-Learning Algorithms in Control Systems for Heat and Power Consumption of Buildings. *AVOK [AVOK – Association of Engineers for Heating, Ventilation, Air-Conditioning, Heat Supply and Building Thermal Physics]*, (4). Available at: [https://www.abok.ru/for\\_spec/articles.php?nid=7229](https://www.abok.ru/for_spec/articles.php?nid=7229) (Accessed 10 December 2020) (in Russian).
10. Altunin K. A., Sokolov M. V. (2016) Application of Neural Networks for Modeling the Turning Process. *Vestnik TGTU [Bulletin of Tambov State Technical University]*, 22 (1), 122–133 (in Russian).
11. Popov O. V., Popova Yu. B., Yatsynovich S. V. (2018) Determination of Limiting Resistance for Dilatant Soil to Shearing while Using Artificial Neural Networks. *Nauka i Tekhnika = Science and Technique*, 17 (6), 471–477. <https://doi.org/10.21122/2227-1031-2018-17-6-471-477> (in Russian).
12. Popova Yu. B., Yatsynovich S. V. (2017) Software Implementation of an Artificial Neural Network for Managing Virtual Objects. *Sistemnyi Analiz i Prikladnaya Informatika = System Analysis and Applied Information Science*, (4), 72–78. <https://doi.org/10.21122/2309-4923-2017-4-72-78> (in Russian).
13. Tarkhov D. A. (2005) *Neural Networks. Models and Algorithms*. Moscow, Radiotekhnika Publ. 256 (in Russian).

Поступила 16.12.2020

Подписана в печать 23.02.2021

Опубликована онлайн 30.07.2021

Received: 16.12.2020

Accepted: 23.02.2021

Published online: 30.07.2021